

<特集「AIが切り拓く医療の未来」>

## 人工知能時代の放射線医学

酒井 晃二\*, 山田 恵

京都府立医科大学大学院医学研究科放射線診断治療学

### Radiology in the Era of Artificial Intelligence

Koji Sakai and Kei Yamada

*Department of Radiology,*

*Kyoto Prefectural University of Medicine Graduate School of Medical Science*

#### 抄 録

人工知能 (artificial intelligence: AI) は3度目のブームを迎えていると言われる。放射線医学領域においても、診療業務効率の上昇等による医師不足の解決やワークライフバランスの改善を目的にAI導入の検討が行われている。

放射線医学領域への導入が図られているAIの多くは、画像の特徴を利用して有益な情報を抽出し、診断や治療方針の決定、または予後予測などに役立てることが目的とされている。これらAIのアルゴリズムには、機械学習 (machine learning: ML) の一つである深層学習 (deep learning: DL) などが用いられている。

本報では、AIとその基礎となるMLとの関係を概説し、放射線医学領域で検討されているものを例に、ML関連研究のトレンドを概観する。また、画像を用いたDLの例を概観し、AI開発の問題点、今後のAI開発の展開について述べる。

キーワード：放射線医学，人工知能，機械学習，深層学習，畳み込みニューラルネットワーク。

#### Abstract

Artificial intelligence (AI) is said to have reached its third boom. In the radiology field, the implementations of AI is being carried out for the solution of doctor shortage and improvement of work-life balance. Many AIs that are being introduced into the field of radiology use deep learning (DL), which is one of machine learning (ML). The DL is used in the algorithm for AI system, which extracts useful information for diagnosis, determining a treatment strategy, and prognostication by using image features. This paper outlines the relationship between AI and its underlying ML and trends in research related to ML, taking as an example what is being considered in the field of radiology. In addition, we will outline the example of DL using medical images and describe the problems of AI development. Finally, we will discuss about the future

---

平成31年4月25日受付 平成31年4月25日受理

\*連絡先 酒井晃二 〒602-8566 京都市上京区河原町通広小路ル梶井町465番地

sakai3@koto.kpu-m.ac.jp

doi:10.32206/jkpum.128.06.407

developments of AI in radiology.

**Key Words:** Radiology, Artificial intelligence, Machine learning, Deep learning, Convolutional neural network.

## はじめに

人工知能 (artificial intelligence: AI) はこれまでの2度のブームを経て、今また3度目のブームを迎えていると言われる<sup>1)</sup>。AIはいたる所で喧伝され、様々な産業、業態で導入が検討され、すでに実用化されているものもある<sup>2)</sup>。今回のブームは、画像や音声などの入力に対する認識性能およびその処理技術が向上したこと、Graphics Processing Unitに代表されるコンピュータ処理の高速化<sup>3)</sup>など、前回2度のAIブーム当時とは情報技術 (information technology: IT) 関連の環境が大きく異なっている。

このようにさまざまな導入例を有するようになったAIを医療に応用する目的として、医療における社会的問題の解決が挙げられている。例えば、医療費60兆円問題<sup>4)</sup>、医師の不足および偏在の問題<sup>5)</sup>などがある。医療ばかりでなく、新たな日本の社会像としてSociety 5.0<sup>6)</sup>が想定されており、IT化社会 (Society 4.0) の次に位置づけられている。Society 5.0では、サイバー空間と現実空間が有機的に結び付けられ、社会

問題の解決に役立てようとする計画がある。医療においても内在する問題を解決するため、サイバー空間の主役であるAIを利用しようとする仕組みづくりが試みられている<sup>7)</sup>。

放射線医学領域においても、診療または業務効率の上昇等を目的にAI導入の検討が行われている。導入が検討されているAIの多くは、画像の特徴を利用して、診断、治療方針の決定、予後予測等に有益な情報を抽出するものや、情報を統合して意思決定に役立てることを目的としている<sup>8)</sup>。そのアルゴリズムには、機械学習 (machine learning: ML) の一つである深層学習 (deep learning: DL) が3度目のブームを受けて多く用いられるようになってきた。

以下では、AIとその基礎となるMLとの関係を概説し、放射線医学領域で検討されているML関連研究の近年のトレンドについて脳病変を例として概観する。また、ごく最近検討が盛んに行われているDLを用いた代表的な研究例および開発例を放射線医学領域以外と放射線医学領域に分けて概観する。さらに、AI開発の問題点に言及する。最後に、今後のAI開発の展開について

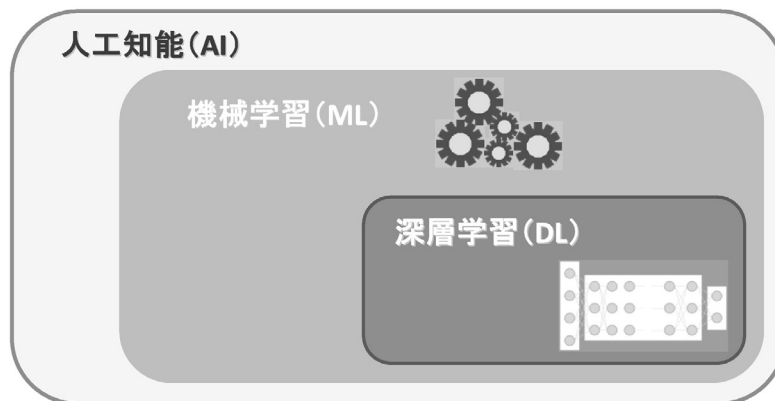


図1 AIとML, DLの包含関係

て述べる。

## AIとML

### 1. AIとMLの関係

ブリタニカ国際大百科事典<sup>9)</sup>によると、AIとは、「人工的な手段で実現され、知覚、インタラクション、推論（推理）、問題解決、言語、連想、学習などの知的情報処理を自律的に遂行することができる情報処理メカニズム。」と定義されている。図1に、AIとML、DLの包含関係を示す。

MLはAIを構成する要素の一つであるが、放射線医学領域では、MLの一種であるDLを用いた知的情報処理システムもAIと呼ばれることが多くなっている。MLは、大きく教師有り学習と教師なし学習に大別される。

教師有り学習では、例えば、良性または悪性腫瘍のように確定診断が行われている症例（これを正解データという）からデータの特徴を算出し、それらに基づく良悪の分類モデルを生成

する。その後、新規の症例に対してその分類モデルを適用し、診断を推論する。一方、教師なし学習では、膨大な数のデータを利用し、それらから特徴量を求め、パターンやカテゴリ分類を行う。正解が定まっていないデータ群の特徴発見、傾向分析・予測を行う目的に利用される。

主なMLとして、support vector machine (SVM)、random forest (RF)、convolutional neural network (CNN)などの教師有り学習が放射線医学領域の研究に用いられている<sup>10)</sup>。CNNのうち、convolution層を多層化したものをdeep neural network (DNN)、またはDLと呼ぶ。分類や予測の精度を高くするためには、多数の学習用および検証用データを必要とする。次節に代表的な脳病例研究における使用データ数の統計値を示す（図3（d））。

### 2. 放射線医学領域のML

#### 1) MLとComputer Aided Diagnosis (CAD)

放射線医学領域におけるMLの利用は、1998年のマンモグラフィCADシステム

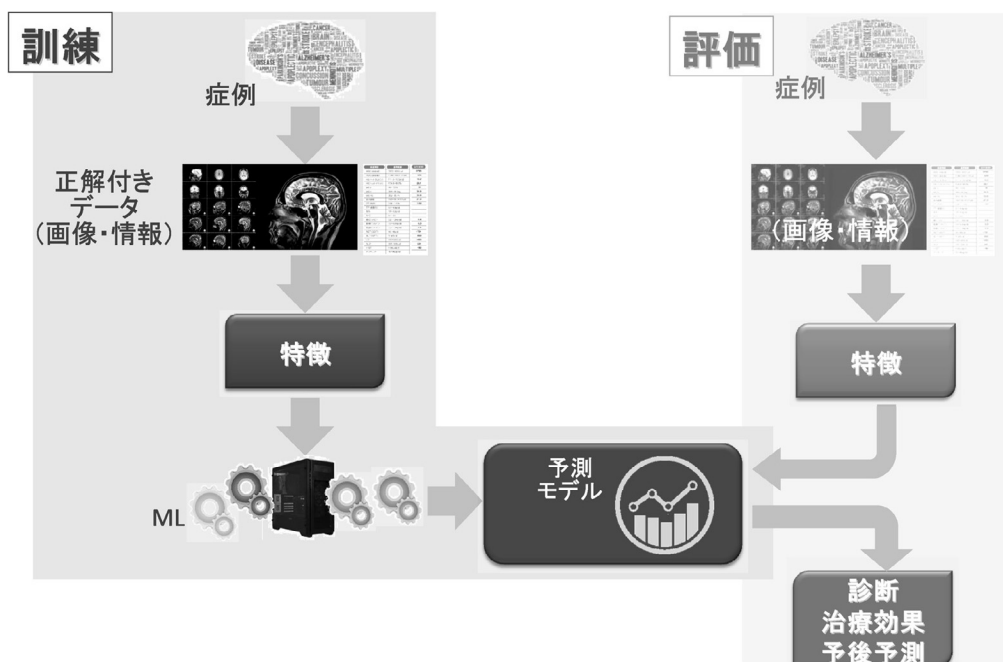


図2 MLの代表的なワークフロー

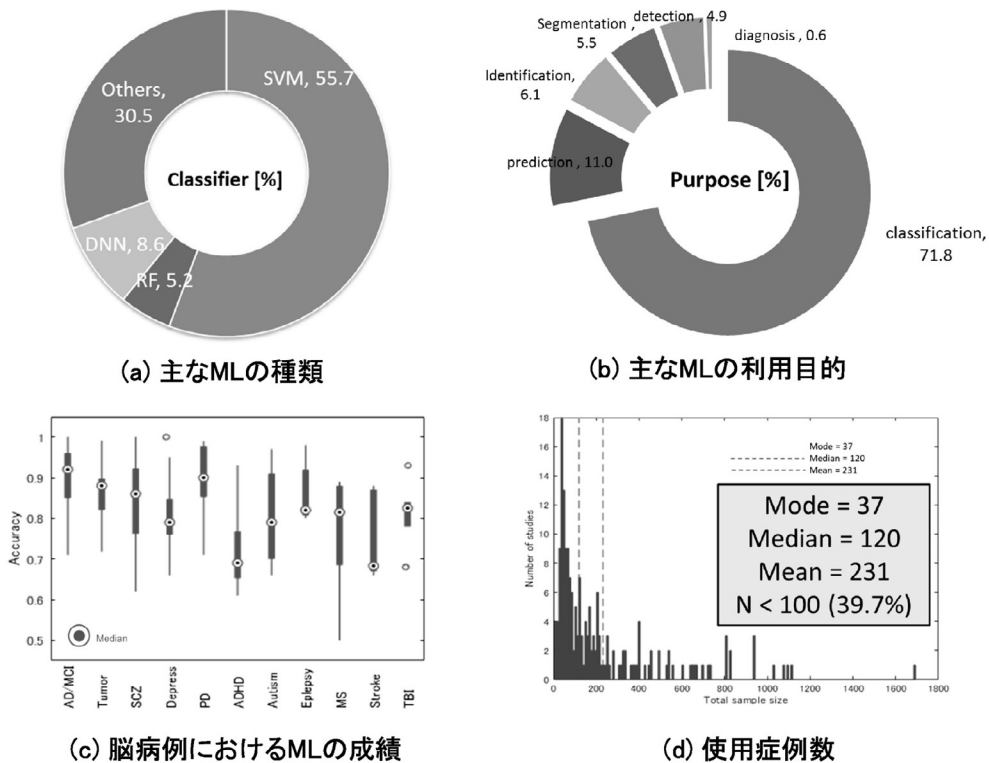
「ImageCheckerR」(R2 Technology社)の実用化に代表される。1998年は、CAD元年とも呼ばれる<sup>11)</sup>。このシステムでは、画素値に基づく画像特徴抽出技術が用いられており、教師あり学習により悪性腫瘍の特徴をモデル化している。医師が読影した後に、システムに医師が指定した腫瘍位置を入力して判定を行う。これにより2名の医師が確認するいわゆるダブルリーディングを1名の医師で実現するものとして、米国Food and Drug Administration (FDA)の認可を受けている<sup>12)</sup>。CADは、コンピュータ解析の結果を「第二の意見」として提供するものであり、最終診断は医師により行われる。

## 2) MLの応用

図2に、放射線医学領域に用いられているMLの代表的なワークフローを示す。

一般的にMLでは、まず、正解付きデータセットにおいて、正解と画像特徴、またはその他の検査情報との関係を学習する(図2の訓練)。この際、正解と画像特徴や検査情報との関係を数式等で明確に求める(予測モデルと呼ばれる)方法と、正解と情報との関係は明確ではないが、結果を正しく提出させるためのアルゴリズムまたはネットワーク上の重み付けを構築するものがある。DLは、後者にあたる。DLの仕組みは次項に示す。

図3に、代表的な脳病例研究に用いられている(a) MLの種類と(b) 主な利用目的、(c) 成績、(d) 使用症例数を示す。図3は、最近4年間(2015-2018年)に報告された文献のうち、報告例が多い上位10症例(Alzheimer's disease: AD, tumor, schizophrenia: SCZ, depression:



(略語)

AD: Alzheimer's disease, SCZ: schizophrenia, PD: Parkinson's disease, ADHD: attention-deficit hyperactivity disorder, MS:

図3 代表的な脳症例研究におけるMLの利用

Depress, Parkinson's disease: PD, attention-deficit hyperactivity disorder: ADHD, autism, epilepsy, multiple sclerosis: MS, stroke, traumatic brain injury: TBI) で入手可能な209件から作成されたものである<sup>10)</sup>.

図3において、代表的な脳病例研究に利用されているMLとしては、SVMが最も多く(55.7%)、病変のクラス分類に多く利用され(71.8%)、それらの精度は概ね0.7-0.9であり、研究に使用された症例数の中央値は120例であった。脳領域以外を含めたDL研究の例は、第3章2節に示す。

### 3) DLの仕組み

DLは、現在の放射線医学領域におけるAI研究の主軸になっている。DLの画像処理研究分野への進展は、2012年開催された世界的な画像認識の技術大会であるImageNet Large Scale Visual Recognition Challenge (ILSVRC2012)において、ニューラルネットワーク(neural network: NN)を改良したDLが画期的な画像認識率を示したことに端を発すると言われている<sup>13)</sup>。放射線医学領域で検討されているDLには様々なものがあるが<sup>14)</sup>、一般的なDLの概要<sup>15)</sup>を図4に示した(実際にはより複雑であり、隠れ層内部

にもさまざまな工夫が行われている<sup>14)</sup>が、概念の理解のため、単純化して示した)。図4において、データは丸印で示されている。DLでは、入力層から始まる各データを重みづけ加算して次の丸印に移行する(これを、畳込み: convolutionという)ネットワーク構造が特徴である。

DLは、入力情報に対して、各種の処理を行い、それらの畳込みを行った後、最終的に判断モデルとしてのネットワークを構築して結論に到達する(convolutional NN: CNNと呼ばれる)。隠れ層を多段階にしたものをdeep CNN、または、一般にdeep learning (DL)と呼ぶ。DLでは、学習に用いる入力情報が多ければ多いほど、隠れ層の各層で決定される要素の重みは変化し、ネットワークの予測精度は高くなる。一方、ネットワーク構造の各層において決定される各要素の重みが出力結果に対してどのように意味づけられるかは不明なままとなっていた。現在では、ネットワークの各層が着目して結果に影響を与えた部分を可視化する手法(例えば、Grad-CAM<sup>16)</sup>)も提案されており、ネットワーク構造のすべてがブラックボックスであるということではなくなっている。すなわち、現時点では実現されていないが、DLにより選択され

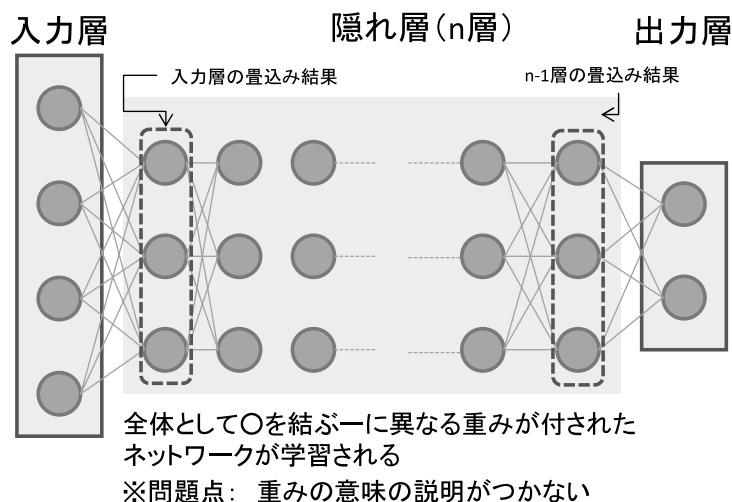


図4 DLの概要

た結果を理由づけができる可能性があり、使用側の納得感を得られるAIシステムが構築される可能性も出てきている。

## 医用画像へのDLの応用

現在までにDLは、様々な医用画像処理に応用されて来ている<sup>17)</sup>。医用画像のうち、眼底写真、皮膚病変写真や病理組織画像などにDLが利用されている。以下には、放射線医学領域以外の医用画像を用いたDL研究とシステムの例、および放射線医学領域におけるDL研究の例を示す。放射線医学領域では、主にX線像、MRI、CT、PET/SPECT画像および超音波画像を所掌しているため、他の医用画像とは別項で述べる。

### 1) 放射線医学領域以外の画像を用いたDL

以下に、放射線医学領域以外の医用画像を用いたDL研究・システムの例を示す(表1)。

医用画像に対するDL利用のうち、内視鏡画像は最も進んでいるものの一つである。Hirasawaraは、内視鏡によるDL胃癌検索システムを発表しており、検証に用いた77個の胃癌中、71個を感度92.2%で診断した<sup>18)</sup>。また、大腸の内視鏡画像を解析するAIソフトウェアEndoBRAINRは、2018年末に医薬品医療機器等法の製造販売承認を取得し、2019年3月に市販が開始されている。EndoBRAINRに用いられている解析エンジンは、

学習済みのSVMにより判断モデル生成しているため、DLのように学習数の追加による診断性能の変化を生じないことは特徴的である<sup>19)</sup>。

眼底写真(網膜眼底画像)を用いたAIシステムにおいても研究と実用化が進んでいる。心血管危険因子を284,335人の患者眼底写真から学習したモデルは、12,026人と999人の2つの独立した患者データセットにおける検証において、年齢などの網膜像に存在または定量化できないと考えられていた心血管危険因子を予測した<sup>20)</sup>。また、眼底写真から糖尿病関連眼疾患を特定するAIソフトウェアIDx-DRは、2018年に米国FDAの販売認可を取得している<sup>21)</sup>。

皮膚病変写真へのDL利用も成果を挙げている。Estevaら<sup>22)</sup>は、皮膚病変写真を9種の皮膚病に分類する課題において、Googleが一般公開しているGoogLeNet(Inception-v3)を用いて、皮膚科医と同等の診断性能を示す(正診率:皮膚科医=53.3%, CNN-PA=55.3%)ことを報告した。CNN-PAとは、part alignment-based method generates parts by using co-segmentation and alignmentを意味し、CNNの一種である。また、Haenssleら<sup>23)</sup>は、メラノーマの皮膚鏡画像鑑別において、58人の皮膚科医とDLを比較し、DLがすぐれた結果を示した(AUC:皮膚科医=0.79, DL=0.86)ことを報告した。AUC

表1 医用画像を用いたDL研究・システムの例(放射線医学領域以外)

| 画像      | 対象         | 成績等                               | 文献 |
|---------|------------|-----------------------------------|----|
| 内視鏡画像   | 胃癌検出       | 感度=92.2%                          | 18 |
|         | 大腸癌検出      | EndoBRAIN®(薬機法承認済)*               | 19 |
| 眼底写真    | 心血管危険因子予測  | AUC: 性別=0.97, 喫煙=0.71, 収縮期血圧=0.70 | 20 |
|         | 糖尿病関連眼疾患特定 | IDx-DR(FDA承認済)                    | 21 |
| 皮膚病変写真  | 9種の皮膚病分類   | 正診率: 皮膚科医=53.3%, CNN-PA=55.3%     | 22 |
|         | メラノーマ      | AUC: 皮膚科医=0.79, DL=0.86           | 23 |
| 病理スライド像 | 乳がんのリンパ節転移 | AUC: 病理医=0.966, DL=0.994          | 24 |

\*EndoBRAINにはSVMが用いられているが、承認済ソフトウェアとして特記するために記載した。  
AUC: ROC曲線下面積(AUC: area under the curve)  
CNN-PA: part alignment-based method generates parts by using co-segmentation and alignment  
DL: deep learning

は、area under the receiver operating characteristic curveを意味する。

さらに、乳がんのリンパ節転移の病理スライドによる検出においても、DLが病理医よりもわずかに優れていること（AUC：病理医＝0.966，DL＝0.994）が報告されている<sup>24)</sup>。

## 2) 放射線医学領域の画像を用いたDL

放射線医学領域では、主にX線像，MRI，CT，PET/SPECT画像，超音波画像を対象としてDL研究が行われている。表2に、主なDL研究の例を示す。

胸部単純X線像を用いた結核の検出において、Lakhaniら<sup>25)</sup>は、2つの異なる公開CNN（AlexNetおよびGoogLeNet）を使用し、画像を肺結核の徴候を有するものと健常なものに分類した。胸部X線撮影上で結核はAUC=0.99の精度で分類された。また、14種類の肺疾患の検出する研究<sup>26)</sup>では、10万件以上の胸部単純X線像を元にCheXNetと名付けられた121層の隠れ層を有するCNNモデルを利用して、その鑑別精度を

4，7，25，28年の経験を有する4名の放射線科医と比較した。CheXNetは、放射線科医の平均値よりよい結果（F1 score: CheXNet=0.435，放射線科医平均=0.387）を得たと報告されている。

小児の手根骨のレントゲン写真を用いた骨年齢評価の研究<sup>27)</sup>では、CNNモデルを訓練し検証するために、2施設から得られた14,036件のレントゲン写真とそれに対応する放射線科専門医によるレポートが教師データとして用いられた。CNNモデルと放射線科医による骨年齢推定値の平均差は0歳であった。CNNモデルは、専門の放射線医と同等の正確さで骨格の成熟度を推定できたことが報告されている。

非造影CTから水頭症、急性期脳梗塞を検出するためのCNNアルゴリズムの性能を評価した研究<sup>28)</sup>では、水頭症は、感度90%，AUC=0.91の性能で検出され、脳梗塞は、感度62%，特異度96%，AUC=0.81の性能で検出された。頭部非造影CTからCNNを用いて、頭部の重要所見を自動検出することが期待される。また、肝臓CTに

表2 医用画像を用いたDL研究・システムの例（放射線医学領域）

| 画像      | 対象            | 方法                 | 成績等  | 文献 |
|---------|---------------|--------------------|--|----|
| 胸部単純X線像 | 結核の検出         | AlexNet, GoogLeNet | AUC=0.99   | 25 |
|         | 14種類の肺疾患の検出   | CheXNet            | F1 score: CheXNet=0.435, 放射線科医=0.387                         | 26 |
| レントゲン写真 | 骨格成熟度評価       | CNN                | 鑑別モデルと放射線科医の差=0歳   | 27 |
| CT      | 水頭症、急性期脳梗塞の検出 | CNN                | 水頭症:感度90%, AUC=0.91, 脳梗塞:感度62%, 特異度96%, AUC=0.81             | 28 |
|         | 肝臓線維症の分類      | CNN                | 肝腫瘍の鑑別:AUC=0.84, カテゴリー分別:AUC=0.92                            | 29 |
|         | 肝臓腫瘍の病期分類     | CNN                | 線維症(≥F2): AUC=0.74, 進行性線維症(≥F3): AUC=0.76, 肝硬変(F4): AUC=0.73 | 30 |
| MRI     | 脳動脈瘤の検出       | CNN                | AUC=0.942  | 31 |
|         | MRIシーケンスの自動識別 | AlexNet, GoogLeNet | AlexNet: 中央=73.6%, 最初=73.1%<br>GoogLeNet: 中央=98.1%, 最初=94.8% | 32 |
|         | 合成CT生成        | CNN                | 平均絶対誤差=84.8±17.3 HU  | 33 |
| 乳腺超音波像  | 病変分類          | GoogLeNet          | AUC=0.942, 感度86%, 特異度96%                                     | 34 |

における線維症の分類<sup>29)</sup>では、12層のCNNを用いて、55,536セットのダイナミックCTにおける5カテゴリーの肝腫瘍の鑑別が行われた。100症例の鑑別テストにおいて、肝腫瘍の鑑別診断の精度は0.84であった。カテゴリーを分別するためのAUCは0.92であった。肝線維症のCT画像に基づくCNNによる病期分類の可能性もYasakaら<sup>30)</sup>により調査されている。線維症、進行性線維症および肝硬変を診断するためのAUCは、それぞれ0.74, 0.76, 0.73であり、Yasakaらは、これらを中程度の診断性能と評価した。

頭部MRIでは、磁気共鳴血管造影 (magnetic resonance angiography: MRA) 画像を用いて、頭蓋内動脈瘤の検出を目的に、CNNを用いたシステム開発が行われている<sup>31)</sup>。300例の画像でトレーニングした検出モデルを100症例で性能評価した結果、当該システムは、1症例あたり2.9の偽陽性を伴う94.2%の精度で動脈瘤を検出した。

MRIを用いて頭部用MRIシークエンスを自動分類することも試みられている<sup>32)</sup>。正常と軽度認知障害を有する78人の患者、および形態学的に変形した頭部MR画像を有する78人の頭蓋内出血患者の6つのMRIシークエンス (T2強調画像, FLAIR, T2\* 強調画像, 拡散強調画像, ADCマップ, およびMRA) を、AlexNetおよびGoogLeNetによって分類した。AlexNetは、各グループの中央スライスで、73.6%の選択精度を示し、頭頂部のスライスで、73.1%の精度を示した。一方、GoogLeNet, それぞれ98.1%, および94.8%であった。また、MRIを用いて合成CT像を生成することにもCNNが応用されている。放射線治療計画を作成する目的において、不必要な放射線被曝を減少させるため、CTをMRIに置き換えることに関心が高まっている。線量計算はCTに基づいた理論が用いられているため、MRIから合成CT値を導出する方法が必要とされている。Hanらにより、27層のCNNを用いて、18人の脳腫瘍患者のT1強調画像からCT像が合成された<sup>33)</sup>。CT像と合成CT像の全平均絶対誤差は、全被験者で $84.8 \pm 17.3$  HUであり、アトラスに基づく従来法 ( $94.5 \pm 17.8$  HU)

より有意に優れていたと報告されている。

乳腺超音波画像において、Hanら<sup>34)</sup>は、4254個の良性病変および3154個の悪性病変を含むデータセットをGoogLeNetを用いて鑑別した。病変領域の指摘は放射線画像診断医によるため、完全な自動システムではないが、AUC=0.9, 感度86%, 特異度96%の精度を達成している。

## AI開発の問題点

AIシステムの医学領域への導入は、その意義や要望などからできるだけ早い実現が期待されている。しかしながら、AI導入が実現されるまでには、解決されなければならない開発上のいくつかの問題点がある。以下にその代表的なものを示す。

### 1. 学習データの不足問題

#### 1) 施設間データ統合の難しさ

一般的に、個々の医用画像生成装置 (MRIなど) が出力する画像の間には違いがあることが知られている<sup>35)</sup>。それは、装置メーカー間のハードウェアの違いに基づく撮像パラメータの推奨値の違い、または、出力信号に対するフィルター等の後処理方法の違いなどによる。それらの違いを反映した画像は、たとえ同一メーカーの同型の装置であったとしても、基本的には異なる画像であり、統一的に扱うには別途検証を必要とする。

#### 2) 教師データ作成の困難

訓練を受けた放射線科専門医の意思決定プロセスのすべてを数字や文字で表現し、コンピュータに分かりやすい形で入力することは不可能である。そのため、すべての病態や症例において網羅的に教師データを収集することが難しいことが指摘されている<sup>36)</sup>。一方で、先に述べた超音波内視鏡の例のように、MLにより多くのデータから診断モデルを構築し、補助的に利用することにより、正診率が向上する病態があることも事実である。そのため、より多くの教師データを収集する努力が行われている。教師データ作成に際しては、医師による判断が基準にされることが多い。例えば、病変の辺縁を決定する (領域抽出) には医学的知識が必要であ



る。そのため、病変の領域抽出は、医師の手動により決定されることが多い。しかしながら、この作業は多くの時間を必要とするため、より簡便に教師データを作成するツールの開発が望まれる。

## 2. データの所有権

医療施設等における検査の結果（データ）の所有権は、法律的には患者の個人情報と位置付けられている。そのため、その保護とAIシステム開発とを共存させるため、様々な条件が付されている。倫理委員会による審査、患者の了解、監査機構の導入など個人情報を保護するための仕組みはより強化されている。AIシステム構築のための最重要事項である良質なデータ収集に対して、個人情報保護は、非常に大きな関連事項である。インフォームドコンセントのプロセスが不十分なために法律違反を問われたAI研究もある<sup>37)</sup>。開発促進と個人情報保護のバランスと社会的なコンセンサスの形成が重要である<sup>38)</sup>。

## 3. 医療機器承認の問題

医療機器は商品化に際して、医薬品医療機器総合機構<sup>39)</sup>の承認を得なければならない。AIを活用した医療機器の、薬事承認審査基準については、難しい課題も指摘されている。DLでは、図4に示したように判断課程の全容が明らかにされておらず、なぜその結果に至ったのかを医学的知識に基づいて説明することができていない。したがって、AI医療機器には、ブラックボックス性、学習数による性能の継続的な変化、学習データの質により性能の優劣が生じることなど、問題点が指摘されている<sup>40)</sup>。

## 放射線医学領域におけるAI開発の展開

世界的な潮流として、放射線医学領域においてはAIシステムに対する関心は非常に高い。様々な学会において多数のAI関連セッションが設けられ、結果の検討、議論が継続されている。また、DLを用いた研究報告も年々増加している<sup>41)</sup>。AIおよびDLには、数学的・情報学的に複雑な内容が含まれてるが、放射線科医がこれまでに統計学を学んで役立ててきたように、これらを積極的に学ぶことも推奨されている<sup>8)</sup>。日本

放射線医学会総会では、DLの具体的な使用方法に関するセッションが大会期間中を通じて開催されるなど、積極的な教育活動を展開しており、放射線医学領域におけるコンピュータプログラミングに対する重要性が増している。コンピュータプログラミングに精通した放射線科医の活躍の場は益々増えてゆくものと思われる。

本稿で示した問題点に対しても、様々な対応が取られ始めている。施設間データの統合に関しては、北米放射線学会が、quantitative imaging biomarker alliance (QIBA)<sup>42)</sup>を組織し、定量的な計測手法に関する議論を先導している。日本においても、日本放射線医学会、日本磁気共鳴医学会によりJ-QIBAが組織され、取り組みが始まっている<sup>43)</sup>。

データ不足の問題については、全日本的なデータベースの整備が進んでいる。現在、日本医療研究開発機構の採択課題の一つとして、日本医用画像データベースプロジェクト (J-MID) が進行中である<sup>44)</sup>。

教師データの作成については、腫瘍領域などの自動抽出手法が検討されており<sup>45)46)</sup>、現状はまだ不完全であるが、将来的には全自動によるアノテーションデータ生成も期待される<sup>47)</sup>。また、医療データの所有権については、個人情報保護法等を遵守しながら医療情報を収集するための仕組みづくりが行われている<sup>48)</sup>。

医療機器の承認問題については、前述のようにAI内視鏡ソフトウェアの例や眼底画像の診断システムなどの承認例があり、DL構造に由来する問題点を解決する可能性がある。

## おわりに

放射線医学領域では、積極的なAIの研究開発と問題点の解決、臨床応用を目的とした教育にも力点が置かれており、人工知能時代への準備は着実に進められている。AIの積極的な導入は、放射線医学領域の診療および業務を効率化し、意思決定の高速化、診断および治療の品質保持、業務分担の最適化などの達成に寄与するものと期待される。

山田恵は、(株)ドクターネット、シーメンズ(株)、日本メジフィジックス(株)、第一三共(株)、富士製薬(株)、富士

フィルムRIファーマ(株)より研究費を受領している。

酒井晃二は、開示すべき潜在的利益相反状態はない。

## 文 献

- 1) “人工知能の歴史”. 総務省. <http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h28/html/nc142120.html>, (参照2019-04-09)
- 2) “IBM Watson 活用例”. IBM. <https://www.ibm.com/watson/jp-ja/use-cases/>, (参照2019-04-09)
- 3) Ben naceur M, Saouli R, Akil M, Kachouri R, Fully Automatic Brain Tumor Segmentation using End-To-End Incremental Deep Neural Networks in MRI image. *Computer Methods and Programs in Biomedicine*, 166: 39-49, 2018.
- 4) “医療と介護を取り巻く現状と課題等”. 中医協. <https://www.mhlw.go.jp/file/05-Shingikai-12404000-Hokenkyoku-Iryouka/0000167844.pdf>, (参照2019-04-09)
- 5) “医師の不足，偏在の是正を図るための方策”. 日本医師会勤務医委員会答申. <http://dl.med.or.jp/dl-med/kinmu/kinmu21.pdf>, (参照2019-04-09)
- 6) “Society 5.0”. 内閣府. [https://www8.cao.go.jp/cstp/society5\\_0/index.html](https://www8.cao.go.jp/cstp/society5_0/index.html), (参照2019-04-09)
- 7) “Society 5.0時代のヘルスケア”. 経団連. [https://www.keidanren.or.jp/policy/2018/021\\_gaiyo.pdf](https://www.keidanren.or.jp/policy/2018/021_gaiyo.pdf), (参照2019-04-09)
- 8) Kobayashi Y, Ishibashi M, Kobayashi H, How will “democratization of artificial intelligence” change the future of radiologists? *Japanese Journal of Radiology*, 37: 9-14, 2019.
- 9) ブリタニカ国際大百科事典. <https://kotobank.jp/dictionary/britannica/>, (参照2019-04-18)
- 10) Sakai K, Yamada K, Machine learning studies on major brain diseases: 5-year trends of 2014-2018. *Japanese Journal of Radiology*, 37: 34-72, 2019.
- 11) 土井邦雄, コンピュータ支援診断 (CAD) に関する世界の情勢 *MEDICAL IMAGING TECHNOLOGY* Vol.21 No.1 January 2003.
- 12) 長谷川玲, 世界で初めて商用化されたマンモグラフィ用 CAD -ImageCheckerR-. *日本放射線技術学会雑誌*, 56: 355-358, 2000.
- 13) 藤田広志. AIがもたらすCADシステムの変革. *INNERVISION*, 32: 10-13, 2017.
- 14) Ueda D, Shimazaki A, Miki Y, Technical and clinical overview of deep learning in radiology. *Japanese Journal of Radiology*, 37: 15-33, 2019.
- 15) Mazurowski MA, Buda M, Saha A, Mustafa R, Bashir MD, Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. *J Magn Reson Imaging*, 49(4): 939-954, 2019.
- 16) Philbrick KA, Yoshida K, Inoue D, Akkus Z, Kline TL, Weston AD, Korfiatis P, Takahashi N, Erickson BJ, What does deep learning see? Insight from a classifier trained to predict contrast enhancement phase from CT image. *American Journal Neuroradiology*, 211: 1184-1193, 2018.
- 17) Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciampi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal*, 42: 60-88, 2017.
- 18) Hirasawa T, Aoyama K, Tanimoto T, Ishihara S, Shichijo S, Ozawa T, Ohnishi T, Fujishiro M, Matsuo K, Fujisaki J, Tada T, Application of artificial intelligence using a convolutional neural network for detecting gastric cancer in endoscopic images. *Gastric Cancer*, 21: 653-660, 2018.
- 19) “AIを搭載した大腸内視鏡診断支援ソフトウェア医薬品医療機器等法 (薬機法) 承認のお知らせ”. <https://prtimes.jp/main/html/rd/p/000000331.000004714.html>, (参照2019-04-19)
- 20) Poplin R, Varadarajan AV, Blumer K, Liu Y, McConnell MV, Corrado SG, et al. Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning. *Nature Biomedical Engineering*, 2: 158-164, 2018.
- 21) “FDA permits marketing of artificial intelligence-based device to detect certain diabetes-related eye problems”. FDA. <https://www.fda.gov/newsevents/newsroom/pressannouncements/ucm604357.htm>, (参照2019-04-19)
- 22) Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542: 115-118, 2017.
- 23) Haenssle HA, Fink C, Schneiderbauer R, Toberer F, Buhl T, Blum A, et al. Man against machine. diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in

- comparison to 58 dermatologists. *Ann Oncol*, 29: 1836-1842, 2018.
- 24) Ehteshami Bejnordi B, Veta M, Johannes van Diest P, van Ginneken B, Karssemeijer N, Litjens G, et al. Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. *JAMA*, 318: 2199-2210, 2017.
- 25) Lakhani P, Sundaram B. Deep Learning at Chest Radiography: Automated Classification of Pulmonary Tuberculosis by Using Convolutional Neural Networks. *Radiology*, 284: 574-582, 2017.
- 26) Rajpurkar P, Irvin J, Zhu K, Yang B, Mehta H, Duan T, et al. CheXNet: radiologist-level pneumonia detection on chest X-rays with deep learning. 2017.arXiv: 1711.05225.
- 27) Larson DB, Chen MC, Lungren MP, Halabi SS, Stence NV, Langlotz CP. Performance of a deep-learning neural network model in assessing skeletal maturity on pediatric hand radiographs. *Radiology*, 287: 313-322, 2018.
- 28) Prevedello LM, Erdal BS, Ryu JL, Little KJ, Demirer M, Qian S, et al. Automated critical test findings identification and online notification system using artificial intelligence in imaging. *Radiology*, 285: 923-931, 2017.
- 29) Yasaka K, Akai H, Abe O, Kiryu S. Deep learning with convolutional neural network for differentiation of liver masses at dynamic contrast-enhanced CT: a preliminary study. *Radiology*, 286: 887-896, 2018.
- 30) Yasaka K, Akai H, Kunimatsu A, Abe O, Kiryu S. Deep learning for staging liver fibrosis on CT: a pilot study. *Eur Radiol*. 2018. <https://doi.org/10.1007/s00330-018-5499-7>.
- 31) Nakao T, Hanaoka S, Nomura Y, Sato I, Nemoto M, Miki S, et al. Deep neural network-based computer-assisted detection of cerebral aneurysms in MR angiography. *J Magn Reson Imaging*, 47: 948-953, 2018.
- 32) Noguchi T, Higa D, Asada T, Kawata Y, Machitori A, Shida Y, et al. Artificial intelligence using neural network architecture for radiology (AINNAR): classification of MR imaging sequences. *Jpn J Radiol*. 2018. <https://doi.org/10.1007/s11604-018-0779-3>.
- 33) Han X. MR-based synthetic CT generation using a deep convolutional neural network method. *Med Phys*, 44: 1408-1419, 2017.
- 34) Han S, Kang HK, Jeong JY, Park MH, Kim W, Bang WC, Seong YK. A deep learning framework for supporting the classification of breast lesions in ultrasound images. *Phys Med Biol*, 15; 62(19): 7714-7728, 2017.
- 35) Sasaki M, Yamada K, Watanabe Y, Matsui M, Ida M, Fujiwara S, Shibata E; Acute Stroke Imaging Standardization Group-Japan (ASIST-Japan) Investigators. Variability in Absolute Apparent Diffusion Coefficient Values across Different Platforms May Be Substantial: A Multivendor, Multi-institutional Comparison Study. *Radiology*, 249: 624-630, 2008.
- 36) Yamada K and Susumu M, The day when computers read between lines. *Japanese Journal of Radiology* 2019 Mar 25. doi: 10.1007/s11604-019-00833-3. [Epub ahead of print]
- 37) 笹原英司. “医療分野におけるAIとレギュラトリーサイエンス, 期待と課題”. <https://www.slideshare.net/esahara/ai-79388720>, (参照 2019-04-09)
- 38) Price WN 2nd, Cohen IG, Privacy in the age of medical big data, *Nat Med*, 25(1): 37-43, 2019.
- 39) 医薬品医療機器総合機構. <https://www.pmda.go.jp/>, (参照 2019-04-15)
- 40) “平成29年度 次世代医療機器・再生医療等製品評価指標作成事業”. 人工知能分野審査WG報告書. [http://dmd.nihs.go.jp/jisedai/Imaging\\_AI\\_for\\_public/H29\\_AI\\_report\\_v2.pdf](http://dmd.nihs.go.jp/jisedai/Imaging_AI_for_public/H29_AI_report_v2.pdf), (参照 2019-04-09)
- 41) Saba L, Biswas M, Kuppli V, Cuadrado Godia E, Suri HS, Edla DR, Omerzu T, Laird JR, Khanna NN, Mavrogeni S, Protogerou A, Sfikakis PP, Viswanathan V, Kitas GD, Nicolaidis A, Gupta A, Suri JS, The present and future of deep learning in radiology. *Eur J Radiol*, 114: 14-24, 2019. doi: 10.1016/j.ejrad.2019.02.038. Epub 2019 Mar 2.
- 42) Kessler LG, Barnhart HX, Buckler AJ, et al.: The emerging science of quantitative imaging biomarkers 9 JSMI Report terminology and definitions for scientific studies and regulatory submissions. *Stat Methods Med Res*, 24: 9-26, 2015.
- 43) 青木茂樹, 萩原彰文: QIBAにおける画像の定量化と標準化のシステムづくり. *INNERVISION*, 32, 33-34, 2017.
- 44) “理事長挨拶”. 日本医学放射線学会. [http://www.radiology.jp/jrs\\_about/greeting.html](http://www.radiology.jp/jrs_about/greeting.html), (参照 2019-04-22)
- 45) Wong Yuzhen N, Barrett S. A review of automatic lung tumour segmentation in the era of 4DCT. *Rep Pract Oncol Radiother*, 24(2): 208-220, 2019.
- 46) Chen H, Dou Q, Yu L, Qin J, Heng PA. VoxResNet: Deep voxelwise residual networks for brain segmentation from 3D MR images. *Neuroimage*, 15; 170: 446-455, 2018.

47) Lavdas I, Glocker B, Kamnitsas K, Rueckert D, Mair H, Sandhu A, Taylor SA, Aboagye EO, Rockall AG, Fully automatic, multiorgan segmentation in normal whole body magnetic resonance imaging (MRI), using classification forests (CFs), convolutional neural net-

works (CNNs), and a multi-atlas (MA) approach. *Med Phys*, 44(10): 5210-5220, 2017.

48) “個人情報保護法等を遵守しながら，医療情報を収集するために”，宮内・水町IT法律事務所，<http://www.miyauchi-law.com/iryu.html>，(参照2019-04-22)

## 著者プロフィール



酒井 晃二 Koji Sakai

所属・職 京都府立医科大学大学院医学研究科放射線診断治療学  
臨床AI研究講座・准教授

略 歴 2004年3月 岩手県立大学大学院ソフトウェア情報学研究所 修了  
2004年4月 京都大学 高等教育研究開発推進センター  
2007年10月～2008年9月

Johns Hopkins University, School of Medicine, Department of  
Radiology, Visiting faculty

2009年10月 京都大学大学院医学研究科人間健康科学系

2015年1月 京都府立医科大学大学院放射線診断治療学  
先端的磁気共鳴画像研究講座

2018年4月～現職

専門分野：医用画像解析

- 主な業績：1. Sakai K, Kei Yamada, Machine learning studies on major brain diseases: 5-year trends of 2014-2018, *Japanese Journal of Radiology*, **37**: 34-72, 2019.
2. Goto M, Sakai K, Yokota H, Kiba M, Yoshida M, Imai H, Weiland E, Yokota I, Yamada K, Diagnostic performance of initial enhancement analysis using ultra-fast dynamic contrast-enhanced MRI for breast lesions, *European Radiology*, **29**: 1164-1174, 2019.
3. Sparacia G, Cannella R, Re VL, Mamone G, Sakai K, Yamada K, Miraglia R, Brain core temperature of patients before and after orthotopic liver transplantation assessed by DWI-thermometry, *Japanese Journal of Radiology*, **36**: 324-330, 2018.

## 著者プロフィール



## 山田 惠 Kei Yamada

所属・職：京都府立医科大学大学院医学研究科放射線診断治療学・教授

略 歴：1989年 京都府立医科大学医学部卒業

1989年 京都府立医科大学病院研修医，放射線科勤務

1991年 聖マリアンナ医科大学病院研修医，放射線科勤務

1994年 アメリカ合衆国メリーランド大学リサーチ・フェロー

1995年 アメリカ合衆国ロチェスター大学クリニカル・フェロー

1997年 アメリカ合衆国マサチューセッツ総合病院クリニカル・フェロー

1998年 京都府立医科大学病院修練医，放射線科勤務

1999年 京都府立医科大学病院助手，放射線科勤務

2003年 京都府立医科大学病院講師，放射線科勤務

2012年 京都府立医科大学病院教授，放射線科勤務

現在に至る

専門分野：画像診断学（特に中枢神経）

主な業績：1. Yamada K, et al. MR imaging of the mamillothalamic tract. *Radiology*, **207**: 593-598, 1998.

2. Yamada K, et al. Clinically feasible diffusion-tensor imaging for fiber tracking. *Radiology*, **227**: 295-301, 2003.

3. Konishi J, Yamada K, et al. MR tractography for the evaluation of functional recovery from lenticulostriate infarcts. *Neurology*, **64**: 108-113, 2005.

4. Kinoshita M, Yamada K, et al. Fiber-tracking does not accurately estimate size of fiber bundle in pathological condition. *Neuroimage*, **25**: 424-429, 2005.

5. Yamada K, et al. Somatotopic organization of thalamocortical projection fibers as assessed by MR tractography. *Radiology*, **242**: 840-845, 2007.

6. Nagakane Y, Yamada K, et al. Acute lenticulostriate infarction presenting with skip lesions may reflect the selective vulnerability of gray and white matter. *Stroke*, **39**: 494-496, 2008.

7. Yamada K. Diffusion tensor tractography should be used with caution (letter). *Proc Natl Acad Sci U S A*, **106**: E14, 2009.

8. Kudo K, Sasaki M, Yamada K, et al. Differences in CT perfusion maps generated by different commercial software: quantitative analysis by using identical source data of acute stroke patients. *Radiology*, **254**: 200-209, 2010.

9. Ota M, Sato N, Sakai K, Yamada K, et al. Altered coupling of regional cerebral blood flow and brain temperature in schizophrenia compared with bipolar disorder and healthy subjects. *J Cereb Blood Flow Metab*, **34**: 1868-1872, 2014.

10. Yuh WT, Yamada K, et al. Revisiting Current Golden Rules in Managing Acute Ischemic Stroke: Evaluation of New Strategies to Further Improve Treatment Selection and Outcome. *AJR Am J Roentgenol*, **208**: 32-41, 2017.

11. Matsuoka T, Imai A, Fujimoto H, Kato Y, Shibata K, Nakamura K, Yokota H, Yamada K, Narumoto J. Reduced Pineal Volume in Alzheimer Disease: A Retrospective Cross-sectional MR Imaging Study. *Radiology*, **286**: 239-248, 2018.

